

サポートベクターマシンを用いた複数の均衡点をもつ 税率変化の予測手法

A Method of Predicting Changes of Tax Rates Equilibrium in Multitude by Support Vector Machine

今福啓*

Kei Imafuku

Email: k03082@dokkyo.ac.jp

本研究では、他者から影響をうけて意思決定する個人からなる社会をモデル化し、その社会で実現される将来的な税率の予測手法を提案する。モデル化した社会では、個人が持つ周期的な非合理性が相互に影響するため、この社会での望ましい税率は複数の均衡点を持ち、その個数と値が時間とともに変化する。税率の変化を予測するため、本研究では教師あり学習手法であるサポートベクターマシンを多段的に用いて、税率の将来的な変化を予測する手法を提案する。そして、コンピュータシミュレーションを行い、その結果から提案手法の有効性を考察する。

In this paper, we create a model of the society which consists of an individual who makes decision influenced from the others, and propose a method to predict the desirable tax rates which will be realized in the future. In the modeled society, the individual has a periodic irrationality and makes influence mutually. Therefore, a desired tax rates has a large number of equilibrium, therefore the numbers and the values change with time. For the purpose of predicting vary of the tax rates, we propose a method which uses a support vector machine in multistage. Through the simulation results, we consider the effectiveness of the proposed method.

*: 獨協大学経済学部

1. はじめに

社会はさまざまな考えを持つ、多様な個人の集合から構成されている。また、個人は意思決定の場面において、社会的に他者から影響を受けることが知られている⁽¹⁾。そのため、我々を取り巻く社会状況が複雑に変化する様子を、政治や文化、産業など、さまざまな場面でみることができる。

将来的にわれわれの社会はどのようなものか、それを予測することは重要である。予測を通じて、何らかの危機的な状況が起こりうることが判明すれば、事前に回避するための策を講じることが可能となるためである。しかし、人と社会が相互に影響をあたえることで複雑に変化する状況では、そのような予測を行うことは容易ではない。

複雑に変化する社会状況を、どのように分析し、予測すれば良いだろうか。一つの方法として、コンピュータ内部で個人の行動を模倣し、それを集合させて社会を構築してシミュレーションを行い、得られた結果の分析を通じて行う手法があげられる。この手法では、個人の意思決定を個別に表現できるため、個々に異なる意思決定や、意思決定時の他者からの影響過程を取り入れることが容易となる。また、コンピュータ内部ではすべてのデータを取得できる。そのため、シミュレーションで生じた将来に至るまでの状況を時系列として記録し、分析に利用することも可能である。

しかし、過去に社会で生じた現象を単に記録しただけでは、将来どのような状況が生じるのかについて知ることはできない。記録した結果からその特徴を抽出し、現在の状況から将来生じる状況を予測することが必要である。

先行研究では具体的な問題として、社会での望ましい消費税率と所得税率の予測を行った⁽²⁾。その際、実社会での人の意思決定を模倣した社会を構築するため、個人の意思決定に非合理性が生じる状況をモデル化した。そして、将来的な税率変化の予測を行う手法として、サポートベクターマシンの関数近似を用いる手法を提案した。社会全体で望まれる税率は複数の均衡点を生じるが、意思決定に非合理性がある場合は、点の値だけでなく個数も時間とともに変化する。予測の簡単化のため、先行研究ではそのうちの1点のみの変化に着目して予測を行った。

本研究は、1点だけでなく複数の均衡点の変化を予測することを目的とする。しかし、点の位置だけでなく個数も変化する状況を予測する手法はみられないため、本研究では複数の均衡点の遷移する領域を、サポートベクターマシンを多段的に用いて予測する手法を提案する。そして、シミュレーション結果から提案手法の有効性を検討する。

2. 税率決定のモデルと提案する予測手法

この章では、本論文で構築する社会モデルで使用する税率の計算モデルと、そのモデルに付加する行動主体が意思決定時に生じるゆらぎのモデル、行動主体間の相互作用を決めるつながりのモデル、そして税率の予測手法を述べる。

2.1 税率決定と意思決定時のゆらぎのモデル

本研究では「退職者と労働者の2世代重複モデル」⁽³⁾にもとづき、社会での望ましい消費税および所得税の税率を計算する手法を、構成する社会モデルの一部として用いる。このモデルは、多数の個人から構成される社会において、各個人の賃金獲得能力が対数正規分布にしたがい、下方に偏っていると仮定する。図1に、厚生労働省が行った平成21年度の所得分布⁽⁴⁾を対数正規分布により近似した例を示す。横軸は所得金額、縦軸は各所得を獲得する世帯の割合である。例えば横軸が2における所得は100万～200万であり、縦軸はその割合が12.7%であることを表す。実際の所得分布は、平均値(547.5万円)が中央値(427万円)よりも大きくなっており、下方に偏るという対数正規分布の特徴と一致していることがわかる。したがって、賃金獲得能力が対数正規分布にしたがうという仮定は妥当であると考えられる。

各個人は労働供給と消費を行う際に、個々に異なる賃金獲得能力から計算される効用関数を最適化して得た政策選好にもとづき、それぞれが最も望ましいと考える賃金税率と消費税率を計算する。社会に適用される税率は、全有権者の政策選好を反映する構成員からなる、賃金税率と消費税率を別々に決定する各委員会において、多数決投票により決められる。その際、他のすべての投票に勝つことのできるコンドルセ勝者とよばれる状態となった値が、採用される税率となる。




図1 平成21年度調査の所得分布と対数正規分布(緑の点が実際の所得分布、赤い線が対数正規分布による近似)

このモデルでは、人口成長率を n 、利子率を r 、

個人の賃金獲得能力の下限值 E と対数正規分布の平均 μ 、標準偏差 σ を指定すると、偏微分方程式を数値計算により解くことにより社会で採用される税率が求められる。得られる税率の均衡点は、計算に使用するパラメータの値により、一点となる場合と複数点となる場合が生じるが、いずれの場合でも、一度求まるとそれが時間とともに変わることはない。

税率の均衡点の計算例を図2に示す。赤色の実線は、消費税率 t_c が縦軸の値となった場合に、委員会で決定される賃金税率 t_w を表す。また緑色の点線は、 t_w が横軸の値の場合に委員会で決定される消費税率 t_c である。そして交点は青色の+印となるが、これが社会全体に適用される税率となる。個人の意思決定時が合理的に行われるのであれば、将来的な税率決定は複数の均衡点のうち、どの値を税率とするべきかという、政策決定の議論に進むことができる¹。しかし、個々に異なる考えを持つ個人の意思決定は、必ずしも合理的に行われているとはいえない。限定合理性やフレーミング、現状バイアス⁽⁵⁾といった非合理性⁽⁶⁾が意思決定に影響することが明らかとなっており、意思決定に非合理的な部分が存在することは明白といえる。また、個人が意思決定を行う際、単に個人の考えだけでなく他者からの社会的影響過程が存在することが示されている⁽⁷⁾。そのため、非合理性が本研究における個人の税率決定の際に生じれば、均衡点は必ずしも同じ値を維持するとはいえない。ただし、非合理性がホワイトノイズのように変動するのであれば、その結果生じる意思決定には不規則性が生じ、将来の変化を予測することは困難となる。




図2 税率の均衡点

本研究では、異なる個人が意思決定する実社会

¹ 本研究の目的は税率の予測をどのように行うのかという点にあるため、複数の均衡点が存在することを認め、複数の均衡点の変化を予測する方法を検討する。

を模倣するため、 N 人の異なる行動主体をつくり、それを集めて社会を構成する。すべての行動主体は、1時刻ごとに各自にとって望ましい税率を合理的に計算する。そして、行動主体 $i (i = 1, \dots, N)$ が合理的に決定した税率に、自身とつながりのある他者から影響を受けるパラメータにもとづいてノイズを付加することで、非合理性を表現する。

実社会では、集団内で他者の行動に引き込まれることで拍手を引き起こす状況が生じること⁽⁷⁾や、入力信号への同期現象を引き起こす複数の相互抑制結合を持つ神経振動子を用いることで、人間の行うドラム打撃音に合わせてロボットがドラムをたたく同期作業⁽⁸⁾を人工的に実現できることが明らかとなっている。このように、個人が意思決定を行う場面では他者からの影響を受けること、そして周期的な信号が行動に作用して他者と協調、同調する現象が生じると考えられる。本研究では、この現象が非合理性として意思決定時に影響すると仮定し、次式で表現される「蔵本モデル」⁽⁹⁾とよばれる同期現象モデルを用いて非合理性を表現する。

$$\frac{\partial \theta_i}{\partial t} = \omega_i + \frac{K}{N} \sum_{j=1}^N \sin(\theta_i - \theta_j) \quad (1)$$

$(i = 1, \dots, N)$

θ_i, ω_i はそれぞれ振動子 i が持つ位相と固有振動数、 K は結合強度である。式(1)では、 $K = 0$ とすると θ_i はそれぞれ他とは無関係な周期で時間変化する。しかし K をある程度大きな値とすると、 θ_i が一定の位相差を保ちつつ、同一の周期で同期する現象が生じる。図3, 4に、それぞれ $K = 0.05$ (K が大きい) と $K = 0.01$ (K が小さい) の結果を示す。どちらも $N = 3$ である。図3では時間とともに位相が同期していくが、図4では互いに独立した位相となっていることがわかる。このように、 K を大きくすれば他者と同調して意思決定する状況を、小さくすれば他者の意見とは独立して意思決定を行う状況を作り出すことが可能なため、さまざまな社会状況が表現できる。本研究では、個人 $i (i = 1, \dots, N)$ が合理的だと考える望ましい税率に、平均0、標準偏差 $0.01 \sin \theta_i$ にもとづく正規分布に応じたゆらぎを非合理性として加える。




図3 $K = 0.05$ における $\sin \theta_i (i = 1, \dots, 3)$ の時間変化




図4 $K = 0.01$ における $\sin \theta_i$ ($i = 1, \dots, 3$)の時間変化

「退職者と労働者の2世代重複モデル」に、上記の非合理性を追加した結果の例を図5に示す。図5は、指定した期間内に得られたすべての t_w と t_c を1つの図に描画し、その交点となるすべての均衡点を+印で示したものである。図5では、均衡点の集まりが大きく分けて左上、中央、右下の3箇所に見られる。そのうち中央の $x \in [0.156, 0.164], y \in [0.252, 0.26]$ に位置する均衡点が、3つの連続した時刻に変化する様子を赤、青、緑の点で示したものを図6に示す。非合理性の生じない図2と比較すると、図5, 6では非合理性が生じて均衡点が時間とともに変化していることがわかる。また、図6より均衡点が複数存在し、その位置だけでなく個数もtime 1では5点、time 2では1点、time 3では3点と、時刻とともに変化する様子がみてとれる。




図5 意思決定に非合理性が生じる際の税率の均衡点




図6 意思決定に非合理性が生じる際の均衡点の推移

2.2 行動主体間の相互作用

現実の社会における個人間のつながりには、email の送受信メッセージのつながりや学生の友人関係、www のサイト間のつながりがある。このような人が日常的に情報交換を行う際に利用するつながりは、複雑な構造を持ち、個々に異質性を持つとされる⁽¹⁰⁾⁽¹¹⁾。そのため、現実的な社会と同様の特徴をもつ相互作用を構築するモデルで表現するには、各行動主体が持つ式(1)のパラメータを、実社会と同様に複雑かつ異質性を持つネットワーク構造を通じて情報交換する必要がある。

本研究では、世の中に存在するさまざまなネットワークを分析する「複雑ネットワーク⁽¹²⁾」で提案されているネットワークモデルの構築手法により、個人間の関係を表現する。このモデルでは、単純な手順により実社会での人間関係のつながりと同じ特徴をコンピュータ内に作り出すことができる。複雑ネットワークをモデル化する手法は数多く提案されているが、本研究では小さい頂点間距離と大きいクラスター係数という、人間関係をあらわすネットワークに近いモデルを構築可能な「SW 頂点非活性化モデル」を用いる。このモデルでは、最初に一定数 nt_1 の行動主体を選び、そのうちの一方と他のすべてを接続する。そして、接続をもたない行動主体を1つずつランダムに抽出し、確率 p で選択した SW モデルあるいは頂点非活性化モデルという代表的な2つの手法のいずれかを使って、他の行動主体にたいして nt_2 本のネットワークをつないでいくことをくり返し、全ての行動主体間のネットワークを作り出す。

次章では、このように時間経過とともに位置と個数の変化する税率の均衡点が、将来的にどのような値になるのかを予測する手法を提案する。

2.3 税率の予測手法

先行研究では、図3のように時間変化する均衡点のうち、 t_w の値が最も小さい（均衡点のうち左端の）1点の変化のみ予測した。その際、さまざ

まな分野において高い汎化能力を持つことが示されている、サポートベクターマシン (SVM) による関数近似 (support vector regressor: SVR) ⁽¹³⁾ を用いて将来的な変化の予測を行うことが可能であった。しかし、SVR は一つの値がどのように変化するのかを予測する手法であり、図 5, 6 に示した、複数の均衡点の個数と位置が時間とともに変化する状況には適用できない。そのため、本研究では複数ある均衡点の位置の変化を予測する代わりに、均衡点の移動する範囲の変化を SVM で予測する手法を提案する。

SVM は、例えばある状態の患者が病状を有しているのかどうかを判断するといった、2 つの異なるクラスのどちらの状態であるのかを判断する手法として用いることが一般的である。この手法は 2 クラス SVM として知られているが、SVM は 2 つのクラス分類だけではなく、今の状態があるクラスに属するのかそれ以外であるのかといったクラスタリングにも用いることができる。これは 1 クラス SVM とよばれるが、ニューラルネットワークのような学習手法では 1 クラスのクラスタリングは行うことができないため、SVM の利点となっている。本研究では、1 クラスと 2 クラスの SVM を用いて、将来的な税率の均衡点を予測する手法を提案する。

SVM では、学習したい M 個の m 次元入力ベクトル x_i ($i = 1, \dots, M$) が与えられたとき、それが 2 つのクラスのうち、どちらに属するのかを分離する。各入力 x_i のクラスにはラベル $y_i \in \{+1, -1\}$ がつけられる。なお、1 クラス SVM の場合には、+1 となるラベルのデータのみが与えられる。各入力 x_i は、非線形分離関数によりデータを 2 つの領域に分離できるように学習を行う (図 7 参照)。

$$f(x) = w^T \phi(x) + b \quad (2)$$

ここで、 $\phi(x)$ は x を高次元空間に写像する関数、 w は係数ベクトル、 b はバイアス項である。ただし、本研究では 2 つのクラスのデータが複雑な配置となり、厳密な分離関数が得られない状況を避けるため、クラス分けに間違いを許す、ソフトマージン SVM により学習を行う。ソフトマージン SVM では、次式による制約付きの最適化問題を解いて式 (1) の w と b を適切に設定することで、学習データをクラス分けする関数を獲得する。

$$Q(w, b, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^M \xi_i \quad (3)$$

→ minimize

$$\text{s.t. } y_i(w^T \phi(x_i) + b) \geq 1 + \xi_i \quad (4)$$

$$\xi_i \geq 0 \quad (i = 1, \dots, M) \quad (5)$$

ξ_i は、クラス分けの間違いを認める分離関数を求

めるために用いられるスラック変数である。パラメータ C は、誤認識されるデータをどの程度の割合まで認めるのかを決定する重みをあらわす。また、SVM で式 (1) でのクラス分けに必要な $\phi(x)$ を使用したカーネル関数として、次のラジアル基底関数を用いる。

$$K(x, x^T) = \phi^T(x) \phi(x) = \exp \left(-\frac{\|x - x^T\|}{\sigma} \right) \quad (6)$$

SVM では、学習データ (x_i, y_i) ($i = 1, \dots, M$) とパラメータである式 (3) の C 、式 (6) の σ が与えられると、式 (2) の w と b が学習され、正しいクラス分類が可能となる。式 (3) ~ (5) の最適化を行った際、得られる解は必ず大域的最適解となることから、学習結果は常に一意となる。

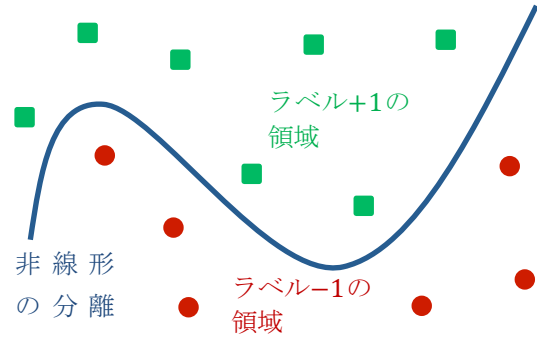


図 7 2 クラス SVM

提案する予測手法は、「学習」と「予測」の 2 つの手順から構成される。「学習」では、過去の一定期間 t_{l_1}, \dots, t_{l_f} に観測済みの均衡点の集合 $x^{t_{l_1}}, \dots, x^{t_{l_f}}$ から²、任意の時刻 t と次の時刻 $t+1$ のデータを使って SVM で学習する。学習の際に使用するデータは過去の均衡点のみであり、他の値は使用しない。「予測」では学習の結果を用いて、 t_{l_f+1} 以降の任意の時刻に得られた税率から、次の時刻に税率がどの範囲となるのかを予測する。また、学習方法の違いから、手法 1 と手法 2 の 2 種類の予測手法を提案する。

手法 1 では、2 つの SVM を用いて学習する。最初に SVM_1 で、過去に実現した均衡点の近傍を 1 つずつ学習する。そして次の時刻に各 SVM_1 の領域内に遷移する点の集合を、 SVM_2 に対応づけて学習する。予測の際は、観測した均衡点が SVM_2 の学習領域に含まれるかをチェックし、含まれる場合には、対応する SVM_1 の領域を次に遷移する均衡点の範囲として予測する。

以下に、手順 1 での学習と予測の詳細な手順を述べる。

² x^t ($t = l_1, \dots, l_f$) は、時刻 t における複数の均衡点を集めたものとなっている。

【手法 1 の学習手順】

1. 時刻 t_{l_1}, \dots, t_{l_f} の全ての均衡点から 1 点ずつ取り出して入力ベクトルとし、そのラベルを+1としたものを、それぞれ 1 クラスの SVM で学習する。ただし、取り出した点がすでに学習済みの SVM の領域に属するならば、その点を改めて学習しない。ここで学習した SVM の個数を n_1 とし、それぞれの SVM を $SVM_1 = (SVM_1^1, \dots, SVM_1^{n_1})$ とする。
2. $SVM_1^1, \dots, SVM_1^{n_1}$ のうち、一つを SVM_1^i とする。任意の時刻 t と $t+1$ の均衡点 x^t, x^{t+1} を取り出す。 x^{t+1} の中に SVM_1^i の領域に入る点が含まれるならば、 x^t のそれぞれ x^t を入力ベクトル、そのラベルを+1として χ_2^i に追加する³。これを、 $t = t_{l_1}, \dots, t_{l_f} - 1$ で実行する。
3. 2.を、 SVM_1^i ($i = 1, \dots, n_1$)にたいして行う。その後、 $\chi_2^1, \dots, \chi_2^{n_1}$ を使って 1 クラスの SVM で学習する。これを $SVM_2 = (SVM_2^1, \dots, SVM_2^{n_1})$ とする。

【手法 1 の予測手順】

1. 任意の時刻 t に観測した全ての均衡点が、 SVM_2 のうちの 1 つである SVM_2^i の学習領域に含まれるかを確認する。すべての点が含まれる場合には、 SVM_1^i を次に遷移する領域として記憶する。
2. 1.を $i = 1, \dots, n_1$ として実行し、1.で記憶した領域のすべてを次に遷移する均衡点の範囲と予測する。

手法 2 では、もう 1 つの SVM を手法 1 の学習に追加する。 SVM_2 では、 SVM_1 に遷移する点のみ学習しているが、追加する SVM_3 は、 SVM_2 の範囲に入る均衡点に対応する SVM_1 に遷移するかどうかを確認し、遷移する点と遷移しない点を分類して 2 クラス SVM で学習する。予測の際には、手順 1 で用いた SVM_2 の代わりに SVM_3 を用いて予測する。

以下に、手順 1 の学習に追加する項目と、手法 2 での予測手順の詳細を示す。

【手法 2 の学習手順 (手法 1 への追加項目)】

4. 任意の時刻 t の均衡点 x^t を取り出す。 x^t のすべてが $SVM_2^1, \dots, SVM_2^{n_1}$ の各領域に含まれるかを確認する。そのうちの 1 つである SVM_2^i の領域に x^t が含まれるとき、次の時刻 x^{t+1} の 1 つが SVM_1^i の領域内となっていれば、 x^t にラベル+1を付与し、 χ_3^i に追加する。1 つも領域内に含まれないならば、 χ_2^i のすべてのラベルを-1としたものを χ_3^i に追加する。
5. 4.を $t = t_{l_1}, \dots, t_{l_f}$ として実行した後に、

$\chi_3^1, \dots, \chi_3^{n_1}$ を用いて 2 クラス SVM で学習を行う。学習した SVM を、 $SVM_3 = (SVM_3^1, \dots, SVM_3^{n_1})$ とする。

【手法 2 の予測手順】

1. 任意の時刻 t に観測した均衡点 x^t が、 SVM_3 のうちの 1 つである SVM_3^i のラベル+1の領域に含まれるかを確認する。 x^t のすべてが含まれる場合には、 SVM_1^i を次に遷移する領域として記憶する。これを $i = 1, \dots, n_1$ として実行し、1.で記憶した領域のすべてを次の均衡点の範囲と予測する。
2. SVM_3 のいずれにも x^t の全てが含まれなかった場合には、しきい値 ρ を設定し、 SVM_3^i の学習領域に入る x^t の割合が ρ を下回った場合に、 SVM_1^i を次に遷移する領域として記憶する。これを $i = 1, \dots, n_1$ として実行し、記憶したすべての領域を次の均衡点の範囲と予測する。

SVM_2 は、 SVM_1 に遷移する領域を学習している。また SVM_3 は、 SVM_2 の領域のうち、 SVM_1 に遷移する領域とそれ以外を分けて学習している。そのため、手法 1 は将来的に遷移する範囲を覆うように予測するのに対し、手法 2 は遷移する範囲をさらに絞り込むよう予測をおこなう。

領域の遷移を予測する手法は、人物追跡問題⁽¹⁴⁾や強化学習の一手法であるインスタンスベース政策学習 (IBP)⁽¹⁵⁾といった他の分野への応用が考えられる。人物追跡問題では人物の移動先を予測することが必要となるが、予測位置の数が時間とともに指数関数的に増加し膨大となる。そこで、膨大な予測点の代わりに移動先を領域とすることで、処理量を大幅に減少させることが可能になると考えられる。

IBP は、ロボットを目的位置に移動する安定化制御則を強化学習により獲得する手法である。IBP では、移動可能な空間 (状態空間) を一つの行動則が有効に機能する領域に分割し、状態一行動の組を学習する。一つの行動則で同一の状態領域に遷移する複数の状態領域を、提案する手法 1 で対応づけて学習することで、複数の状態一行動の組にまとめて従来よりも保持する情報量を減らすことが期待できる。

このように、さまざまな分野において領域の遷移を学習する手法が必要とされるため、提案手法の応用可能性が期待できる。

3. シミュレーション

提案手法を用いたシミュレーションを行った。シミュレーションプログラムは Ruby2.0 で作成し、Windows 7 上で実行した。

3.1 想定する社会状況

社会状況として、個人間の相互作用が大きく他者に同調しやすい状況と、他者からの影響が小さ

³ x^t は複数の均衡点から構成されているため。

⁴ 最初、 $\chi_2^1, \dots, \chi_2^{n_1}$ はすべて空となっている。

く個々の意思が強く影響する状況の2つを想定してシミュレーションを行う。

Case 1 $K = 1.0, \omega_i = [0.5, 0.9]$ のランダムな値

Case 2 $K = 0.25, \omega_i = [0.5, 0.9]$ のランダムな値

Case 1, 2 での行動主体 1 と他の主体との位相差 $\sin(\theta_1 - \theta_i)$ ($i = 2, \dots, 10$) の時間変化を図 8, 9 に示す。Case 1 は K の値が大きいため、全ての行動主体で引き込みが生じ、時間が経過すると位相差が一定となる。それに対して、Case 2 は K が小さいこととネットワーク構造の影響から、一部の行動主体間では引き込みが生じるが、他の行動主体と独立した引き込みの起こらない行動主体も存在する。そのため、位相差が一定とならず常に変化する行動主体の存在する状況が生じる。

実社会では、この2つの違いは「集団主義」および「個人主義」という、文化的価値観の違いを分類した結果に対応するものといえる⁽¹⁷⁾。集団主義は、自分を一つ以上の集団の一部とみなし、集団においてメンバーの団結を重視する人々が織りなす社会パターンをあらわす。それに対して、個人主義は自分が集団から独立しているとみなし、他者よりも自分の目標を優先させることを合理的に判断することが重要と考える人々が織りなす社会パターンをあらわす⁽¹⁸⁾。図 8 は引き込みにより他者とのつながりが強く、集団としての統一的なパターンを示しており集団主義的な色合いが強いが、図 9 は独立した行動主体が他者とは異なるパターンを作りだしており、個人主義の意味合いが強いパターンとなっている。

実社会では、たとえばある時刻に K や ω が変化して Case 1 から Case 2 に移行するといった、データの傾向が任意の時刻を境に過去とは異なる状況に変わることがある。これはコンセプトドリフト⁽¹⁶⁾として知られており、過去のデータをもとに将来のデータ予測を行うことの有効性が損なわれることが示されている。しかし、本研究では簡単化のためにそのような状況の予測については扱わない。




図 8 Case 1 の位相差




図 9 Case 2 の位相差

3.2 シミュレーションの手順

2 章で述べたモデルと手法を用いて、以下の手順にしたがってシミュレーションを行った。

Step 1 時刻 t を初期値 $t = 0$ とし、以下の Step 2, 3 でパラメータの初期値を設定する。

Step 2 社会の人口増加率 r 、利子率 n 、賃金獲得能力の下限值 \underline{E} 、賃金獲得能力の分布を決める対数正規分布の平均値 μ と標準偏差 σ を決める。

Step 3 行動主体 i ($i = 1, \dots, N$) を用意する。非合理性を式(1)にもとづく蔵本モデルで計算するため、各行動主体の位相 θ_i を $[0, \pi)$ の範囲でランダムに設定する。また、固有周波数 ω_i をシミュレーションの Case 1, 2 の値から、行動主体ごとにランダムに決定する。行動主体間のネットワークは、SW 頂点非活性化モデルにもとづき、 (nt_1, nt_2, p) を設定して構築する。

Step 4 各時刻の税率を計算する。最初に、各行動主体にとって望ましい合理的な税率を計算する。そして、税率に平均 0、標準偏差 $0.01\sin\theta_i$ にもとづく正規分布に応じた非合理性を加える。非合理性は蔵本モデルにもとづき毎時刻変化し、SW 頂点非活性化モデルにより接続された他者からのみ影響を受ける。

Step 5 Step 4 の税率をもとに、社会全体での税率を決定する。

Step 6 Step 4, 5 を 1 時刻分の税率として決定した後、 $t := t + 1$ とする。これを時刻 $t = T_f$ まで行い、得られた税率を記録する。

Step 7 2.2 節の方法で、過去に得られた税率を用いた学習と予測を行う。時刻 $t = t_{l_1}, \dots, t_{l_f}$ の税率を SVM で学習し、 $t = t_{p_1}, \dots, t_{p_f}$ の予測を行う。

3.3 パラメータ

税率の近郊点を計算するシミュレーションで利用したパラメータは、行動主体数 $N = 1000$ 、各世代の期間を 25 年として人口増加率 $r = (1.01 - 1)^{25}$ 、利子率 $n = (1.003 - 1)^{25}$ 、賃金獲得能力の下限值 $\underline{E} = 1.2$ 、対数正規分布の平均 $\mu = 0.5$ 、標準偏差 $\sigma = 0.35$ 、SW 頂点非活性化モデルのパラ

メータ(nt_1, nt_2, p) = (100, 10, 0.5)と設定した⁵。税率の決定は $T_f = 2000$ まで行う。そのうち、 $t_{l_1} = 1$ から $t_{l_f} = 200$ を学習データ、 $t_{p_1} = 401$ から $t_{p_f} = 500$ を予測期間とする。提案手法での予測性能を示すため、 t_{p_1} と t_{p_f} を T_f 以内として獲得済みの値を用いる。

税率の均衡点の学習および予測に用いた SVM のパラメータは、手法 1 では $C = 50$ 、 $\sigma = 1.0 \times 10^9$ 、手法 2 では $C = 50$ 、 $\sigma = 1.0 \times 10^8$ とした。SVM₂では、対応するSVM₁に遷移する領域をすべての学習するのに対して、SVM₃はSVM₁に遷移する点としない点を分けて学習する。そのため、SVM₂は次に遷移する領域が大きくなり、SVM₃では狭くなる。SVM では、 σ を小さくすることで学習できる領域を狭くできるが、手法 1 で σ を大きな値とすると、過去に観測した均衡点のすべての領域を覆うように学習してしまうことから、シミュレーションでは手法 1 の σ を手法 2 よりも小さな値とした。なお、手法 2 におけるしきい値は $\rho = 0.5$ とした。 t_{l_1} と t_{l_f} を変更して学習に用いるデータ数を変更することで予測結果が影響を受けると想定されるが、この点の分析は今後の課題とする。

3.4 シミュレーション結果

Case 1 に手法 1, 2 を適用し、各時刻の観測値が SVM での予測範囲に入った割合（これを正解率とする）を図 10, 11 に示す。横軸が時刻、縦軸が正解率である。手法 1 と 2 の正解率の平均値は、それぞれ 0.744、0.642 である。これらの結果から、手法 1 は手法 2 よりも正確に予想しているように見える。しかし、次の時刻の範囲を予測する SVM と実際の均衡点の位置を図示すると、手法 1 が優れているとはいえない。その結果を図 12, 13 に示す。各図の結果は、各手法での正解率が 1 となる点と、予測の外れた点を含む時刻 406 から 410 における SVM と均衡点である。赤色の点が次に移動する範囲を学習した 1 クラス SVM の結果で、緑色の点が実際に移動した点である。グラフの範囲は $x \in [0.162, 0.178]$ 、 $y \in [0.234, 0.25]$ である。また、グラフ中に時刻、グラフの下部に正解率を示している。結果から、手法 1 の予測する領域が多く時刻において左上から右下にかけての広範囲におよぶため、高い正解率となっていることがわかる。それに対して手法 2 では予測範囲が時刻ごとに限定的となり、手法 1 よりも正解率が低くなっている。




図 10 Case 1 での手法 1 の正解率




図 11 Case 1 での手法 2 の正解率




図 12 Case 1 での手法 1 の 405～410 ステップにおける予測範囲と実際の均衡点




図 13 Case 1 での手法 2 の 405～410 ステップにおける予測範囲と実際の均衡点

⁵ これらのパラメータは実社会の状況に厳密にあわせた値ではないため、実証研究を行うには実情にあわせた値を設定することが必要である。本研究は税率の予測可能性に焦点を当てているため、厳密なパラメータ設定は行わない。

Case 1 と同様に、Case 2 における各手法の正解率を図 14, 15 に示す。手法 1 と 2 の正解率の平均値は、それぞれ 0.770、0.652 である。また、図 16, 17 は各手法での SVM の予測範囲と実際の

均衡点である。図 16, 17 の範囲は $x \in [0.166, 0.18], y \in [0.232, 0.246]$ であり、グラフ中に時刻、グラフの下部に正解率を示している。Case 1 と同じく、手法 2 よりも手法 1 の正解率が高い。また図 16, 17 を比較すると、手法 1 の予測する領域が手法 2 よりも広範囲におよぶ、Case 1 と同様の状況が生じている。

各シミュレーション結果は、2.1 節で述べた個々に異なる $\theta_i, \omega_i(1, \dots, N)$ と、それをもとに生じる正規分布にしたがうノイズにより毎回異なるものとなるが、結果の傾向に大きな違いは生じない。




図 14 Case 2 での手法 1 の正解率




図 15 Case 2 での手法 2 の正解率




図 16 Case 2 での手法 1 の 405～410 ステップにおける予測範囲と実際の均衡点




図 17 Case 2 での手法 2 の 425～430 ステップにおける予測範囲と実際の均衡点

3.5 考察

正解率は、いずれの Case においても手法 1 のほうが手法 2 よりも良い結果となっている。しかし、図 12 と図 16 が示す Case 1 での各時刻の予測状況から分かるとおり、SVM での学習範囲に入る割合、すなわち正解率が高いことが正しい予測につながるとはいえない。予測範囲が広くなるよう学習が行われれば、正解率が高くなるためである。図 12 の時刻 408 における予測範囲は、実際の均衡点（図中の緑色の点）が 1 点しかないにもかかわらず、実際の均衡点が複数存在する時刻 409 と同様の状況となっている。図 16 の時刻 410～412 でも、均衡点の位置や個数によらず予測する領域が広範囲である。このような広い予測範囲が得られても、将来の均衡点がどのように変化していくのかという傾向は把握できない。

それに対して手法 2 では、図 13 において時刻 408 では予測範囲が 1 点のみの均衡点の近辺に限定されており、それが時刻 409 で広範囲におよぶ均衡点全体を覆うように予測範囲が変化し、さらに時刻 410 では再び 1 点の均衡点の近傍に変化している。Case 2 のように、他者への相互作用が弱い状況でも、手法 2 では変化の傾向を見ることができる。図 17 では、時刻 428 で 2 つの領域に分離した後、時刻 429 と 430 での均衡点の分布を覆うよう学習しており、均衡点の変化する傾向が見てとれる。手法 2 は予測領域から外れる点もあり、手法 1 よりも正解率は低いものの、均衡点の変化を明確に把握できるため、将来的に遷移する領域を獲得するという、予測により獲得したい情報が得られるといえる。

これらの結果から、予測する領域に入る点と入らない点を分けて学習する手法 2 の SVM_3 が、均衡点の将来的な遷移の傾向を表現する上で有効に機能していると考えられる。

しかし、式(1)において $K = 0.2$ と値が小さく引き込みが生じない場合には、データの傾向を明確にあらわす予測結果が得られなかった。これは、Case 2 よりもさらに他者からの影響を受けず、個人の非合理性の影響が社会全体での税率をランダ

ムに変化させる影響が生じるためではないかと考えられる。手法1のように、学習領域としてある程度の範囲を覆いつつ、手法2のように変化の傾向も示すような、両者の中間的な性質をもつ学習手法が求められる。

4. おわりに

本論文では、意思決定に非合理性をもつ行動主体からなる社会モデルを構築し、将来の税率を予測する手法を提案した。構築した社会モデルでは、各行動主体が実社会と同じ特徴を持つ複雑ネットワークモデルの一つであるSW非活性化モデルにより、他者との相互作用に粗密のあるネットワークで接続される。そして、それぞれに異なる賃金獲得能力を持つ行動主体が合理的に決定する税率に、蔵本モデルをもとにした周期的なゆらぎを生じさせ、意思決定時の非合理性として用いた。構築した社会で生じる税率の均衡点は複数点となるが、点の位置だけでなく数も時刻により変化する。そのため、1クラスおよび2クラスのサポートベクターマシンを多段的に用いて、税率の将来的な変化を予測する手法を提案した。

礎から応用まで」、近代科学社 (2010)

(13) 阿部重夫:「パターン認識のためのサポートベクトルマシン入門」、森北出版 (2011)

(14) 武村紀子、中村泰、石黒浩:「 k 近傍法に基づく予測を用いた人物追跡のための複数エージェントの経路計画法」計測自動制御学会論文集、Vol. 49, No. 5, pp.553-559 (2013)

(15) 土屋千加夫、塩川裕介、池田心、佐久間淳、小野功、小林重信:「ハイブリッドGAによるインスタンスベース政策学習SLIPの提案と評価」計測自動制御学会論文集、Vol. 42, No. 12, pp.1344-1352 (2006)

(16) Fan, W.: Streamminer: "A classifier ensemble-based engine to mine concept-drifting data streams" In: Proc. the 30th Intl. Conf. Very Large Data Bases. Pp.1257-1260 (2004)

(17) Trandis, H. C.: *Individualism and collectivism*, Westview Press (1995)

(18) 守崎誠一:「対人コミュニケーション行動の予測・説明変数としての個人主義/集団主義的価値観:フィリピンの社会人と大学生について」神戸外大論叢、Vol. 58, No. 5, pp.1-19 (2007)

参考文献

- (1) 亀田達也、村田光二:『複雑さに挑む社会心理学 適応エージェントとしての人間』有斐閣アルマ (2000)
- (2) 今福啓:「サポートベクターマシンの関数近似を用いた望ましい所得税率と消費税率の決定手法の提案」進化経済学会、B2-3 (2013)
- (3) 小西秀樹:『公共選択の経済分析』東京大学出版会 (2009)
- (4) 厚生労働省 統計情報・白書 各種統計調査 厚生労働統計一覧 国民生活基礎調査 結果の概要 平成 21 年度国民生活基礎調査の概要 所得の分布状況 : <http://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa09/2-2.html>
- (5) 奥田秀宇:『意思決定心理学への招待』サイエンス社 (2008)
- (6) Ariel, R. (兼田敏之、徳永健一訳):『限定合理性のモデリング』共立出版 (2008)
- (7) 石塚樹、小野哲雄:「拍手に見られる個人-集団間ミクロマクロループ構造のモデル化」信学技報、AI2006-33 (2007)
- (8) 琴坂信哉、Stefen Schaal:「神経振動子を用いたロボットのリズムカルな運動生成」、日本ロボット学会誌、Vol. 19, No. 1, pp.116-123 (2001)
- (9) 蔵本由紀:「いわゆる「蔵本モデル」について」応用数理、Vol. 17, No. 2, pp.175-177 (2007)
- (10) R. Albert, A. L. Barabasi: "Statistical mechanics of complex networks", Review of Modern Physics, Vol. 74, pp.47-92 (2002)
- (11) M. E. J. Newman: "The structure and function of complex networks", SIAM Review, Vol. 45, pp.167-256 (2003)
- (12) 増田直紀、混の紀雄:「複雑ネットワーク 基

(2013年9月30日受付)

(2013年12月18日採録)